



Görüntü İşleme ve Makine Öğrenmesi Kullanılarak Metalik Malzemelerin Boyut Tespiti ve Sınıflandırılması

Tuba YENER^{1*} , Furkan Hasan SAKACI² , Ş.Çağrı YENER³

¹ Metalurji ve Malzeme Mühendisliği Bölümü, Mühendislik Fakültesi, Sakarya Üniversitesi, Türkiye.
tcerezci@sakarya.edu.tr

² Simülasyon ve Otonom Sistemler, HAVELSAN, Ankara, Türkiye. fhsakaci@havelstan.com.tr

³ Elektrik ve Elektronik Mühendisliği Bölümü, Sakarya Üniversitesi, Sakarya Üniversitesi, Türkiye.
syener@sakarya.edu.tr

ÖZ

Metalik malzemelerin makroskobik seviyede boyut ölçümü ve sınıflandırılması endüstriyel proseslerde çeşitli amaç ve yöntemlerde gerçekleştirilen bir işlemdir. Bu çalışmada bakır, alüminyum ve çelik olmak üzere üç farklı metal türüne ait metalik malzemelerin görüntü işleme ile boyut ölçümü ve makine öğrenmesi ile malzeme sınıflarının belirlenmesi gerçekleştirilmiştir. Boyut ölçümünde kullanılan kamera modülü ve alınan görüntü kalitesine bağlı olarak hedeflenen %99.5'in üzerinde doğruluk sağlanmıştır. Farklı makine öğrenmesi yöntemlerinin başarımı ayrı ayrı test edilmiş, Fine KNN ile malzeme sınıflandırması tam doğrulukla gerçekleştirilmiştir.

Anahtar Kelimeler: Metaller, görüntü işleme, makine öğrenmesi, (KNN) K-en yakın komşu algoritması

Dimension Measurement and Classification of Metallic Materials Using Image Processing and Machine Learning

ABSTRACT

In industrial processes, dimension measurement and classification of metallic materials at the macroscopic level are performed for various purposes with various methods. In this study, dimensions of metal materials belonging to three different types such as copper, aluminum and steel have been obtained by using image processing, and their classification has been performed by using machine learning. For the size measurement, over 99.5% accuracy has been achieved based on the quality of the camera module used and the image quality received. The performance of various machine learning methods has been tested for the material classification and the error-free result has been obtained with fine KNN.

Keywords: Metals; image processing; machine learning; KNN (K-nearest neighborhood)

* Sorumlu yazarın e-posta adresi: tcerezci@sakarya.edu.tr

1 Giriş

Görüntü işleme teknikleri üzerindeki gelişmeler çeşitli özellik, model ve kategorize etme yöntemlerini ortaya koyarak malzemelerin sınıflandırılması ve tanımlanmasına olanak sağlamaktadır [1–5]. Görüntülerin işlenmesinde ve sınıflandırılmasında renk, doku, spektral yoğunluk gibi özelliklerden faydalanılır [5–11]. Makine öğrenmesi yöntemlerinin malzeme biliminin farklı alanlarına uygulanması da önemli olanaklar katmaktadır [12].

Malzemelerin makroskobik seviyede boyut ölçümü çok farklı amaç ve yöntemlerle gerçekleştirilen bir işlemdir. Malzeme boyutları ultrasonik, lazer temelli sensörlerle belirlenebilse de, otonom sistemlerde malzeme yerleşiminin uygun olmaması gibi nedenlerle hatalı ölçüm yapılması söz konusu olur. Daha kompleks sistemler ölçüm işlemini gerekli doğrulukta yapabilirler. Fakat bu sistemlerin dezavantajı ilave kapsamlı donanımlar gerektirmeleri ve maliyetli oluşlarıdır. Malzeme boyutlarının görüntü işleme tekniklerinden yararlanarak belirlenmesi hızlı ve ekonomik çözüm sağlayan bir yöntem olmaktadır [13–19].

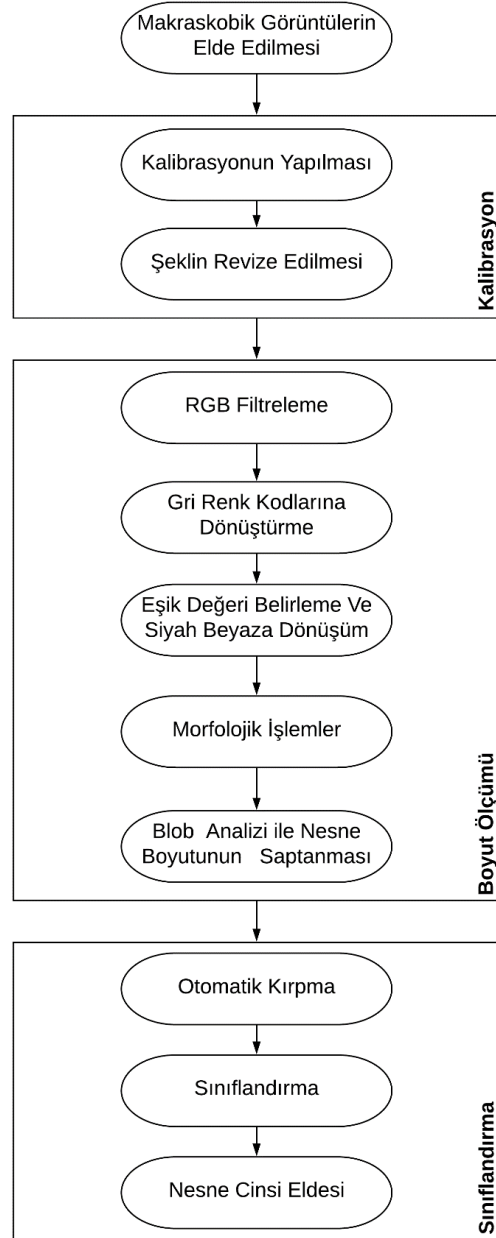
Görüntülerin tanımlanmasında iki temel basamak, özellik çıkarımı ve sınıflandırmadır. Görsellerde özellik çıkarımı için manuel ve otomatik yöntemler uygulanmaktadır. Sınıflandırma için makine öğrenmesi yöntemlerinden destek vektör makinesi (Support Vector Machine, SVM), K-en yakın komşu (K Nearest Neighborhood, KNN) ve ağaç (tree) gibi algoritmalar gerekli doğruluk sağlayan algoritmalar [20–23]. Malzemelerin görüntü işleme teknikleri ile sınıflandırılmasında, mikroskobik görüntülerle daha yüksek başarımlar elde edilebilir. Ancak mikroskobik görüntünün alınmasında; malzemenin uygun boyuta getirilmesi (kesilmesi, kalıplanması), ön hazırlıklar (zımparalama, parlatma, dağlama), görüntüleme ekipmanı üzerinde yapılması gereken ayarlamalar gibi sürecin uzamasına yol açan etmenler söz konusudur. Ayrıca bu yöntemde kullanılan görüntüleme ekipmanlarının yüksek maliyetlidir [24–27]. Bu bağlamda, kolayca erişilebilir ve uygun maliyetli bir kamera modülü ile malzemenin ölçümü ve sınıflandırılmasını gerekli doğrulukta sağlayacak görüntüler hızlı ve ucuz biçimde elde edilebilmesi önemli avantaj sağlamaktadır [13–18,28].

Bu çalışmada farklı metalik malzemelerin görüntü işleme temelli boyut ölçümüne ve sınıflandırılmalarına yönelik yaklaşım ve gerçekleştirme aşamaları sunulmuştur. Hızlı çalışan otonom bir ayrıştırma sistemi için uygun olan bu yöntemle, malzemenin standart bir fotoğraf çekme modülü ile görüntüsünün alınması, ardından bu tek veri ile boyut ve malzeme sınıflandırması olmak üzere iki çıkarım yapılmaktadır.

Bu çalışma aşağıdaki biçimde planlanmıştır: Giriş bölümünün ardından çalışmanın ikinci bölümünde malzeme ölçümü ve sınıflandırılmasına yönelik ele alınan problem tanımlanmış ve gerçekleştirilecek süreç basamakları sunulmuştur. Çalışmanın üçüncü bölümünde malzemenin boyut tespitine yönelik aşamalar, dördüncü bölümünde sınıflandırmaya ilişkin işlem adımları ve elde edilen sonuçlar sunulmuştur. Çalışma sonuçlarına ilişkin son bölümle tamamlanmıştır.

2 Metodoloji

Malzemenin boyutunun tespiti için en temel iki nokta doğru referans uzunluğun belirlenmesi ve görüntünün kalibrasyon işlemi yapılarak ele alınması gerekliliğidir. Referans uzunluğun görüntü işleme algoritması tarafından doğru biçimde belirlenmesi için dama tahtası görünümünde bir referans düzlem kullanılmıştır. İkinci temel işlem basamağı olan sınıflandırma için, algoritmanın hızlı ve yüksek doğruluklu çalışmasına yönelik malzeme referans boyut düzlemi ve boş arka plandan otomatik ayrıştırılarak özellik seçimine yönelik görüntüler oluşturulmuştur. Gerçekleştirilen işlem basamaklarına yönelik süreç adımları Şekil 1’de verilmiştir.

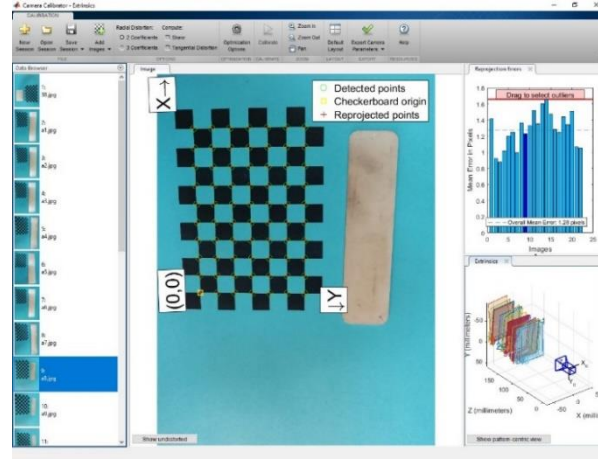


Şekil 1. İşlem basamaklarına yönelik süreç adımları

3 Malzemelerin Boyut Ölçümü

Malzemelerin boyut ölçümünün doğru yapılabilmesi için ilk aşamada ölçüm alınacak ortamın kalibrasyonunun yapılması gerekmektedir. Bu amaçla dama tahtası görünümlü referans düzlemin kalibrasyonu için farklı açılardan fotoğraf alınmıştır. Alınan bu görüntülerle MATLAB™ programında


bulunan Kamera Calibration aracı kullanılarak kalibrasyon parametreleri elde edilmiştir (Şekil 2 a). Alınan ham görüntü ve kalibrasyon sonrası ölçüm referansı için kullanılacak görüntüler sırasıyla Şekil 2 b) ve c)'de verilmiştir. Kalibrasyon işlemi sonrası elde edilen parametreler, oluşturan algoritmaya ilişkin koda aktarılmıştır.



a)



b)



c)


Şekil 2. Ölçüm kalibrasyonuna ilişkin a) MATLAB ortamında Kamera Calibration aracının kullanımı, b) ham görüntü, c) kalibrasyon işlemi sonrası referans uzunluk için kullanılacak görüntü



a)



b)



c)

Şekil 3. Görüntünün işlenmesi ve boyut belirlenmesine yönelik adımlar: a) filtreleme, b) temizleme ve doldurma, c) belirlenen boyutlar.

Kalibrasyon işlemi yapılan fotoğrafta ölçüm alınacak nesnenin saptanabilmesi için öncelikle RGB filtreleme yapılmıştır. Burada arka plan rengi, boyut belirlemesi ve sınıflandırma için kullanılacak metal malzemelerden olabildiğince ayrışacak biçimde seçilmiştir.

Malzemenin saptanabilmesi öncelikle için arka plan ve ölçü referans düzleminin filtrelenmesi gerekmektedir. Bu filtreleme işlemi sonrası elde edilen görüntü Şekil 3 a ile verilmiştir. Bu işlemin ardından görüntü ilk olarak gri tonlara, ardından otomatik eşik (threshold) belirlemesi ile siyah beyaz renklere dönüştürülmüştür. Ardından temizleme ve doldurma işlemleri yapılarak Şekil 3 b)'de verilen görüntü elde edilmiştir. Malzemenin boyutunun belirlenmesi için öncelikle pixel cinsinden en ve boy değerleri belirlenmiştir. Ardından daha önce elde edilmiş kalibrasyon değerleri kullanılarak gerçek ölçüler 32.45 mm ve 198.02 mm olarak belirlenmiştir.

4 Malzemelerin Sınıflandırılması

Cisimlerin hangi malzeme grubuna dahil olduğunu saptamak için ise alüminyum, çelik ve bakır fotoğrafları ayrı ayrı düzenlenmiştir. Düzenlenen bu fotoğraflarda öncelikle otomatik kırpma işlemi yapılmıştır. Daha sonra bu fotoğraflar kullanılarak otomatik özellik çıkarımı yapılmış ve bu özellikler kullanılarak eğitim yapıp eğitim algoritmalarından hangisinin en iyi olduğunu saptamak için Classification Learner aracı kullanılmıştır.

Kullanılan yöntemlerden, KNN, k değerine göre gözlemlerin yapılacağı sınıfı ve en yakın komşuyu belirleyen parametrik olmayan bir sınıflandırma modelidir. KNN, sınıflandırmayı yeni bir noktaya yakın noktalara bakarak, birbirine yakın olan öğelerin aynı kategoriye ait olduğu temeline göre yapar.

SVM yöntemi sınıflandırma ve regresyon analizi için verileri işleyen denetimli öğrenme modelidir. SVM, iki kategori arasındaki boşluğun genişliğini en üst düzeye çıkarmak için eğitim örneklerini uzaydaki noktalara eşler. Yeni örnekler ardından aynı alana eşlenir ve boşluğun hangi tarafına düştüklerine bağlı olarak bir kategoriye ait oldukları tahmin edilir.

Basit Karar Ağacı Analizi, bir veri setini farklı koşullara göre ayırmanın yollarını tanımlayan algoritmik bir yaklaşımla oluşturulan genel tahmine dayalı bir modelleme aracıdır. Denetimli öğrenme için en

yaygın kullanılan yöntemlerden biri olup veri özelliklerinden çıkarılan basit karar kurallarını öğrenerek bir hedef değişkenin değerinin tahmini sağlar.

Bu araç kullanılarak algoritmalara göre başarı oranları Tablo 1 ile verilmiştir.

Tablo 1: Algoritmalara Göre Başarı Oranları

Model Tipi	Başarı (%)
Fine KNN	100
Kubik KNN	82.2
Kubik SVM	97.8
Lineer SVM	93.3
Medium Gaussian SVM	96.7
Basit Ağaç	86.7

0	30		
1		30	
2			30
	0	1	2
	Predicted class		

Şekil 4: Fine KNN modelinin karıştırma matrisi, 0:Alüminyum, 1: Bakır, 2: Çelik

5 Sonuçlar

Bu çalışmada bakır, alüminyum ve çelik olmak üzere üç farklı metal türüne ait malzemelerin görüntü işleme ile boyut ölçümü ve makine öğrenmesi ile malzeme sınıflarının belirlenmesi gerçekleştirilmiştir. Malzeme taşınımı ve ayrıştırması yapan otonom sistemler yanında, görüntünün taşınabilir bir kamera modülü ile operatör tarafından manuel olarak da alınabilmesi, bunun sonucunda yüksek doğruluklu bir sonuç elde edilmesi amaçlanmıştır. Literatürde yapılan benzer çalışmalarda özellikle altın ve gümüş boyutunun ve cinsinin tespitleri yapılmıştır. Yapılan çalışmalarda %90 ile %98 arasında başarı

sağlanmıştır. Boyut ölçümünde kullanılan kamera modülü ve alınan görüntü kalitesine bağlı olarak %99.5'in üzerinde doğruluk sağlanmıştır. Çelik, bakır ve alüminyum gibi ergime sıcaklıklarından mekanik özelliklerine kadar farklı özellik gösteren metalik bağ yapısına sahip malzemelerin ayrıştırılması makine öğrenmesi temelli gerçekleştirilmiş ve başarıyı farklı makine öğrenmesi yöntemleri ile ayrı ayrı test edilmiştir. Fine KNN ile malzeme sınıflandırması tam doğrulukla gerçekleştirilmiştir.

6 Beyanname

6.1 Rakip Çıkarlar

Bu çalışmada herhangi bir çıkar çatışması yoktur.

6.2 Yazarların Katkıları

1. Sorumlu Yazar Tuba YENER: Makaleye katkısı. (Verileri düzenlemek ve raporlamak, araştırma sırasında literatür taraması için sorumluluk almak, sonuçların açıklanması ve sunulması için sorumluluk almak, araştırma sırasında literatür taraması için sorumluluk almak.)

2. Furkan Sakacı: Makaleye katkısı. (Deneylerin yapılması, makalenin tamamının veya ana kısmın oluşturulması için sorumluluk almak, verilerin sadece yazım ve dilbilgisi açısından değil, aynı zamanda entelektüel içerik veya diğer katkılar açısından da yeniden işlenmesini düzenlemek ve raporlamak.)

3. Şuayb Çağrı Yener: Makaleye katkısı. (Araştırma için fikir geliştirmek, sonuçlara ulaşmak için materyal ve yöntemleri planlamak, sonuçların açıklanması ve sunulması için sorumluluk almak, makalenin ana bölümünün oluşturulması için sorumluluk almak.)

Kaynakça

- [1] J. C. Grande, "Principles of Image Analysis," *Metallography, Microstructure, and Analysis*, vol. 1, no. 5, pp. 227–243, Oct. 2012.
- [2] A. Picon, O. Ghita, P. F. Whelan, and P. M. Iriando, "Fuzzy Spectral and Spatial Feature Integration for Classification of Nonferrous Materials in Hyperspectral Data," *IEEE Transactions on Industrial Informatics*, vol. 5, no. 4, pp. 483–494, Nov. 2009.
- [3] N. Salamati and C. Fredembach, "Material Classification Using Color and NIR Images." <https://infoscience.epfl.ch/record/142367/files/SalamatiFS2009.pdf> (accessed February 3, 2019).
- [4] S. Su *et al.*, "Material Classification Using Raw Time-of-Flight Measurements." <https://vccimaging.org/Publications/Su2016MCU/Su2016MCU.pdf> (accessed February 3, 2019).
- [5] M. Strese, C. Schuwerk, A. Iepure, and E. Steinbach, "Multimodal Feature-Based Surface Material Classification," *IEEE Transactions on Haptics*, vol. 10, no. 2, pp. 226–239, Apr. 2017.
- [6] B. Jin, W. Hu, and H. Wang, "Image Classification Based on pLSA Fusing Spatial Relationships Between Topics," *IEEE Signal Processing Letters*, vol. 19, no. 3, pp. 151–154, Mar. 2012.
- [7] G. Wu *et al.*, "Light Field Image Processing: An Overview," *IEEE Journal of Selected Topics in Signal Processing*, vol. 11, no. 7, pp. 926–954, Oct. 2017.

- [8] Bang Zhang, Yang Wang, and Fang Chen, "Multilabel Image Classification Via High-Order Label Correlation Driven Active Learning," *IEEE Transactions on Image Processing*, vol. 23, no. 3, pp. 1430–1441, Mar. 2014.
- [9] G. Schwartz and K. Nishino, "Recognizing Material Properties from Images." <https://arxiv.org/pdf/1801.03127.pdf> (accessed February 3, 2019).
- [10] E. S. Nadimi, J. Herp, M. M. Buijs, and V. Blanes-Vidal, "Texture classification from single uncalibrated images: Random matrix theory approach," in *2017 IEEE 27th International Workshop on Machine Learning for Signal Processing (MLSP)*, 2017, pp. 1–6.
- [11] M. Varma and A. Zisserman, "A Statistical Approach to Material Classification Using Image Patch Exemplars," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 31, no. 11, pp. 2032–2047, Nov. 2009.
- [12] Y. Liu, T. Zhao, W. Ju, and S. Shi, "Materials discovery and design using machine learning," *Journal of Materiomics*, vol. 3, no. 3, pp. 159–177, Sep. 2017.
- [13] J. Rejc *et al.*, "The mechanical assembly dimensional measurements with the automated visual inspection system," *Expert Systems with Applications*, vol. 38, no. 8, pp. 10665–10675, Aug. 2011.
- [14] E. G. Loewen, "High Speed Optical Scanning Techniques for Dimensional Measurement," *CIRP Annals*, vol. 29, no. 2, pp. 513–518, Feb. 1980.
- [15] G. Rosati, G. Boschetti, A. Biondi, and A. Rossi, "On-line dimensional measurement of small components on the eyeglasses assembly line," *Optics and Lasers in Engineering*, vol. 47, no. 3–4, pp. 320–328, Mar. 2009.
- [16] P. Klapetek and T. Dziomba, "Dimensional Measurements," *Quantitative Data Processing in Scanning Probe Microscopy*, pp. 97–149, Jan. 2018.
- [17] B. Chao, Q. Xinghua, L. Yong, L. Yaping, and L. Jingliang, "Dimensional Measurement of Small Hot Pieces Based on a Monochrome CCD," *Procedia Engineering*, vol. 99, pp. 1158–1163, Jan. 2015.
- [18] N. H. Maerz, "Aggregate sizing and shape determination using digital image processing," 1998, pp. 195–203.
- [19] A. Lashgari, S. Ghamami, S. Shahbazkhany, G. Salgado-Morán, and D. Glossman-Mitnik, "Fractal Dimension Calculation of a Manganese-Chromium Bimetallic Nanocomposite Using Image Processing," *Journal of Nanomaterials*, vol. 2015, pp. 1–9, Apr. 2015.
- [20] A. Shayei, M. Abbasi, A. Habiban, M. Shabany, and Z. Kavehvash, "A Machine Learning Approach for Material Classification in MMW Imaging Systems based on Frequency Spectra," in *2018 IEEE International Symposium on Circuits and Systems (ISCAS)*, 2018, pp. 1–5.
- [21] Quan-De Wang, Zhi-Feng Zhong, and Xian-Pei Wang, "Design and implementation of insulators material hydrophobicity measure system by support vector machine decision tree learning," in *2005 International Conference on Machine Learning and Cybernetics*, 2005, pp. 4328–4334 Vol. 7.
- [22] M. J. Mendenhall and E. Merenyi, "Relevance-Based Feature Extraction for Hyperspectral Images," *IEEE Transactions on Neural Networks*, vol. 19, no. 4, pp. 658–672, Apr. 2008.
- [23] T. Aujeszky, G. Korres, and M. Eid, "Thermography-based material classification using machine learning," in *2017 IEEE International Symposium on Haptic, Audio and Visual Environments and Games (HAVE)*, 2017, pp. 1–6.
- [24] B. L. DeCost and E. A. Holm, "A computer vision approach for automated analysis and classification of microstructural image data," *Computational Materials Science*, vol. 110, pp. 126–133, Dec. 2015.
- [25] L. Kunčická, R. Kocich, and T. C. Lowe, "Advances in metals and alloys for joint replacement," *Progress in Materials Science*, vol. 88, pp. 232–280, Jul. 2017.
- [26] A. Pineau, A. A. Benzerga, and T. Pardoen, "Failure of metals I: Brittle and ductile fracture," *Acta Materialia*, vol. 107, pp. 424–483, Apr. 2016.

- [27] Z. Gácsi, “The Application of Digital Image Processing for Materials Science.” <http://www.scientific.net> (accessed February 9, 2019).
- [28] L. Barazzetti and M. Scaioni, “Development and implementation of image-based algorithms for measurement of deformations in material testing.,” *Sensors (Basel, Switzerland)*, vol. 10, no. 8, pp. 7469–95, 2010.



© 2020 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).